20 | Hive + Spark强强联合：分布式数仓的不二之选

2021-10-25 吴磊

《零基础入门Spark》 课程介绍 >

讲述：吴磊
时长 24:00 大小 21.99M

你好，我是吴磊。

在数据源与数据格式，以及数据转换那两讲（第 15、16 讲），我们介绍了在 Spark SQL 之上做数据分析应用开发的一般步骤。

这里我们简单回顾一下：首先，我们通过 SparkSession read API 从分布式文件系统创建 DataFrame。然后，通过创建临时表并使用 SQL 语句，或是直接使用 DataFrame API，来进行各式各样的数据转换、过滤、聚合等操作。最后，我们再用 SparkSession 的 write API 把计算结果写回分布式文件系统。

实际上，直接与文件系统交互，仅仅是 Spark SQL 数据应用的常见场景之一。Spark SQL 另一类非常典型的场景是与 Hive 做集成、构建分布式数据仓库。我们知道，数据仓库指的

是一类带有主题、聚合层次较高的数据集合，它的承载形式，往往是一系列 Schema 经过精心设计的数据表。在数据分析这类场景中，数据仓库的应用非常普遍。

在 Hive 与 Spark 这对“万金油”组合中，Hive 擅长元数据管理，而 Spark 的专长是高效的分布式计算，二者的结合可谓是“强强联合”。今天这一讲，我们就来聊一聊 Spark 与 Hive 集成的两类方式，一类是从 Spark 的视角出发，我们称之为 Spark with Hive；而另一类，则是从 Hive 的视角出发，业界的通俗说法是：Hive on Spark。

Hive 架构与基本原理

磨刀不误砍柴工，在讲解这两类集成方式之前，我们不妨先花点时间，来了解一下 Hive 的架构和工作原理，避免不熟悉 Hive 的同学听得云里雾里。

Hive 是 Apache Hadoop 社区用于构建数据仓库的核心组件，它负责提供种类丰富的用户接口，接收用户提交的 SQL 查询语句。这些查询语句经过 Hive 的解析与优化之后，往往会被转化为分布式任务，并交付 Hadoop MapReduce 付诸执行。

Hive 是名副其实的“集大成者”，它的核心部件，其实主要是 User Interface（1）和 Driver（3）。而不论是元数据库（4）、存储系统（5），还是计算引擎（6），Hive 都以“外包”、“可插拔”的方式交给第三方独立组件，所谓“把专业的事交给专业的人去做”，如下图所示。

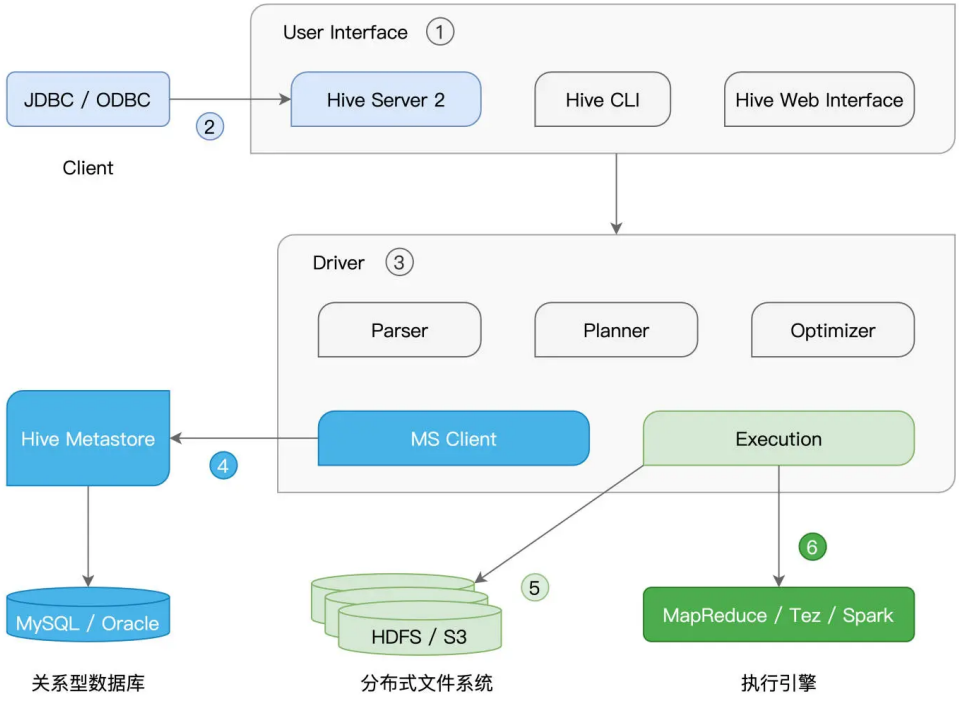

极客时间

Hive架构

Hive 的 User Interface 为开发者提供 SQL 接入服务，具体的接入途径有 Hive Server 2（2）、CLI 和 Web Interface（Web 界面入口）。其中，CLI 与 Web Interface 直接在本地接收 SQL 查询语句，而 Hive Server 2 则通过提供 JDBC/ODBC 客户端连接，允许开发者从远程提交 SQL 查询请求。显然，Hive Server 2 的接入方式更为灵活，应用也更为广泛。

我们以响应一个 SQL 查询为例，看一看 Hive 是怎样工作的。接收到 SQL 查询之后，Hive 的 Driver 首先使用其 Parser 组件，将查询语句转化为 AST（Abstract Syntax Tree，查询语法树）。

紧接着，Planner 组件根据 AST 生成执行计划，而 Optimizer 则进一步优化执行计划。要完成这一系列的动作，Hive 必须要能拿到相关数据表的元信息才行，比如表名、列名、字段类型、数据文件存储路径、文件格式，等等。而这些重要的元信息，通通存储在一个叫作“Hive Metastore”（4）的数据库中。

本质上，Hive Metastore 其实就是一个普通的关系型数据库（RDBMS），它可以是免费的 MySQL、Derby，也可以是商业性质的 Oracle、IBM DB2。实际上，除了用于辅助

SQL 语法解析、执行计划的生成与优化，**Metastore 的重要作用之一，是帮助底层计算引擎高效地定位并访问分布式文件系统中的数据源**。

这里的分布式文件系统，可以是 Hadoop 生态的 HDFS，也可以是云原生的 Amazon S3。而在执行方面，Hive 目前支持 3 类计算引擎，分别是 Hadoop MapReduce、Tez 和 Spark。

当 Hive 采用 Spark 作为底层的计算引擎时，我们就把这种集成方式称作“Hive on Spark”。相反，当 Spark 仅仅是把 Hive 当成是一种元信息的管理工具时，我们把 Spark 与 Hive 的这种集成方式，叫作“Spark with Hive”。

你可能会觉得很困惑：“这两种说法听上去差不多嘛，两种集成方式，到底有什么本质的不同呢？”接下来，我们就按照“先易后难”的顺序，先来说说“Spark with Hive”这种集成方式，然后再去介绍“Hive on Spark”。

Spark with Hive

在开始正式学习 Spark with Hive 之前，我们先来说说这类集成方式的核心思想。前面我们刚刚说过，Hive Metastore 利用 RDBMS 来存储数据表的元信息，如表名、表类型、表数据的 Schema、表（分区）数据的存储路径、以及存储格式，等等。形象点说，Metastore 就像是“户口簿”，它记录着分布式文件系统中每一份数据集的“底细”。

Spark SQL 通过访问 Hive Metastore 这本“户口簿”，即可扩充数据访问来源。而这，就是 Spark with Hive 集成方式的核心思想。直白点说，在这种集成模式下，Spark 是主体，Hive Metastore 不过是 Spark 用来扩充数据来源的辅助工具。厘清 Spark 与 Hive 的关系，有助于我们后面区分 Hive on Spark 与 Spark with Hive 之间的差异。

作为开发者，我们可以通过 **3 种途径**来实现 Spark with Hive 的集成方式，它们分别是：

1. 创建 SparkSession，访问本地或远程的 Hive Metastore；
2. 通过 Spark 内置的 spark-sql CLI，访问本地 Hive Metastore；
3. 通过 Beeline 客户端，访问 Spark Thrift Server。

SparkSession + Hive Metastore

为了更好地理解 Hive 与 Spark 的关系，我们先从第一种途径，也就是通过 SparkSession 访问 Hive Metastore 说起。首先，我们使用如下命令来启动 Hive Metastore。

复制代码

```
hive --service metastore
```

Hive Metastore 启动之后，我们需要让 Spark 知道 Metastore 的访问地址，也就是告诉他数据源的“户口簿”藏在什么地方。

要传递这个消息，我们有两种办法。一种是在创建 SparkSession 的时候，通过 config 函数来明确指定 hive.metastore.uris 参数。另一种方法是让 Spark 读取 Hive 的配置文件 hive-site.xml，该文件记录着与 Hive 相关的各种配置项，其中就包括 hive.metastore.uris 这一项。把 hive-site.xml 拷贝到 Spark 安装目录下的 conf 子目录，Spark 即可自行读取其中的配置内容。

接下来，我们通过一个小例子，来演示第一种用法。假设 Hive 中有一张名为“salaries”的薪资表，每条数据都包含 id 和 salary 两个字段，表数据存储在 HDFS，那么，在 spark-shell 中敲入下面的代码，我们即可轻松访问 Hive 中的数据表。

复制代码

```
import org.apache.spark.sql.SparkSession
import  org.apache.spark.sql.DataFrame

val hiveHost: String = _
// 创建SparkSession实例
val spark = SparkSession.builder()
                    .config("hive.metastore.uris", s"thrift://hiveHost:9083")
                    .enableHiveSupport()
                    .getOrCreate()

// 读取Hive表，创建DataFrame
val df: DataFrame = spark.sql(“select * from salaries”)

df.show

/** 结果打印
+---+------+
| id|salary|
+---+------+
|  1| 26000|
|  2| 30000|
```

```
|  4| 25000|
|  3| 20000|
+---+------+
*/
```

在第 16 讲，我们讲过利用 createTempView 函数从数据文件创建临时表的方法，临时表创建好之后，我们就可以使用 SparkSession 的 sql API 来提交 SQL 查询语句。连接到 Hive Metastore 之后，咱们就可以绕过第一步，直接使用 sql API 去访问 Hive 中现有的表，是不是很方便？

更重要的是，createTempView 函数创建的临时表，它的生命周期仅限于 Spark 作业内部，这意味着一旦作业执行完毕，临时表也就不复存在，没有办法被其他应用复用。Hive 表则不同，它们的元信息已经持久化到 Hive Metastore 中，不同的作业、应用、甚至是计算引擎，如 Spark、Presto、Impala，等等，都可以通过 Hive Metastore 来访问 Hive 表。

总结下来，在 SparkSession + Hive Metastore 这种集成方式中，Spark 对于 Hive 的访问，仅仅涉及到 Metastore 这一环节，对于 Hive 架构中的其他组件，Spark 并未触及。换句话说，在这种集成方式中，Spark 仅仅是“白嫖”了 Hive 的 Metastore，拿到数据集的元信息之后，Spark SQL 自行加载数据、自行处理，如下图所示。

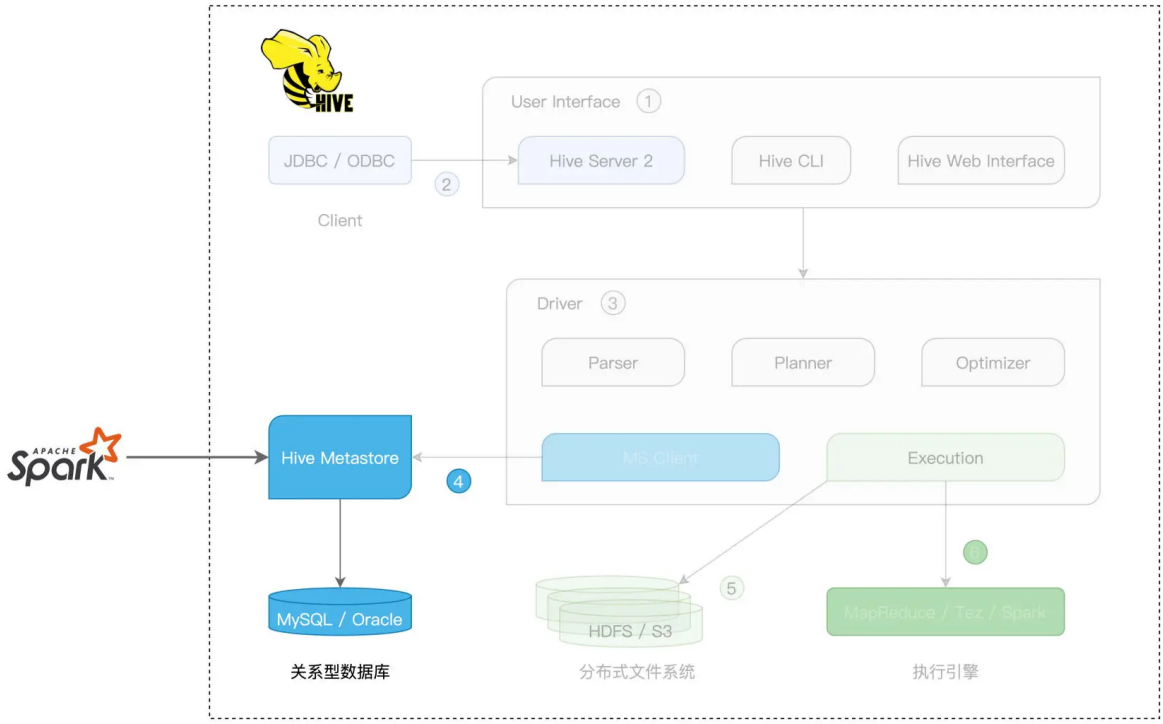

极客时间

SparkSession + Hive Metastore的集成方式

在第一种集成方式下，通过 sql API，你可以直接提交复杂的 SQL 语句，也可以在创建 DataFrame 之后，再使用第 16 讲提到的各种算子去实现业务逻辑。

spark-sql CLI + Hive Metastore

不过，你可能会说：“既然是搭建数仓，那么能不能像使用普通数据库那样，直接输入 SQL 查询，绕过 SparkSession 的 sql API 呢？”

答案自然是肯定的，接下来，我们就来说说 Spark with Hive 的第二种集成方式：spark-sql CLI + Hive Metastore。与 spark-shell、spark-submit 类似，spark-sql 也是 Spark 内置的系统命令。将配置好 hive.metastore.uris 参数的 hive-site.xml 文件放到 Spark 安装目录的 conf 下，我们即可在 spark-sql 中直接使用 SQL 语句来查询或是处理 Hive 表。

显然，在这种集成模式下，Spark 和 Hive 的关系，与刚刚讲的 SparkSession + Hive Metastore 一样，本质上都是 Spark 通过 Hive Metastore 来扩充数据源。

不过，相比前者，spark-sql CLI 的集成方式多了一层限制，那就是在部署上，spark-sql CLI 与 Hive Metastore 必须安装在同一个计算节点。换句话说，spark-sql CLI 只能在本地访问 Hive Metastore，而没有办法通过远程的方式来做到这一点。

在绝大多数的工业级生产系统中，不同的大数据组件往往是单独部署的，Hive 与 Spark 也不例外。由于 Hive Metastore 可用于服务不同的计算引擎，如前面提到的 Presto、Impala，因此为了减轻节点的工作负载，Hive Metastore 往往会部署到一台相对独立的计算节点。

在这样的背景下，不得不说，spark-sql CLI 本地访问的限制，极大地削弱了它的适用场景，这也是 spark-sql CLI + Hive Metastore 这种集成方式几乎无人问津的根本原因。不过，这并不妨碍我们学习并了解它，这有助于我们对 Spark 与 Hive 之间的关系加深理解。

Beeline + Spark Thrift Server

说到这里，你可能会追问：“既然 spark-sql CLI 有这样那样的限制，那么，还有没有其他集成方式，既能够部署到生产系统，又能让开发者写 SQL 查询呢？”答案自然是“有”，Spark with Hive 集成的第三种途径，就是使用 Beeline 客户端，去连接 Spark Thrift Server，从而完成 Hive 表的访问与处理。

Beeline 原本是 Hive 客户端，通过 JDBC 接入 Hive Server 2。Hive Server 2 可以同时服务多个客户端，从而提供多租户的 Hive 查询服务。由于 Hive Server 2 的实现采用了 Thrift RPC 协议框架，因此很多时候我们又把 Hive Server 2 称为“Hive Thrift Server 2”。

通过 Hive Server 2 接入的查询请求，经由 Hive Driver 的解析、规划与优化，交给 Hive 搭载的计算引擎付诸执行。相应地，查询结果再由 Hiver Server 2 返还给 Beeline 客户端，如下图右侧的虚线框所示。

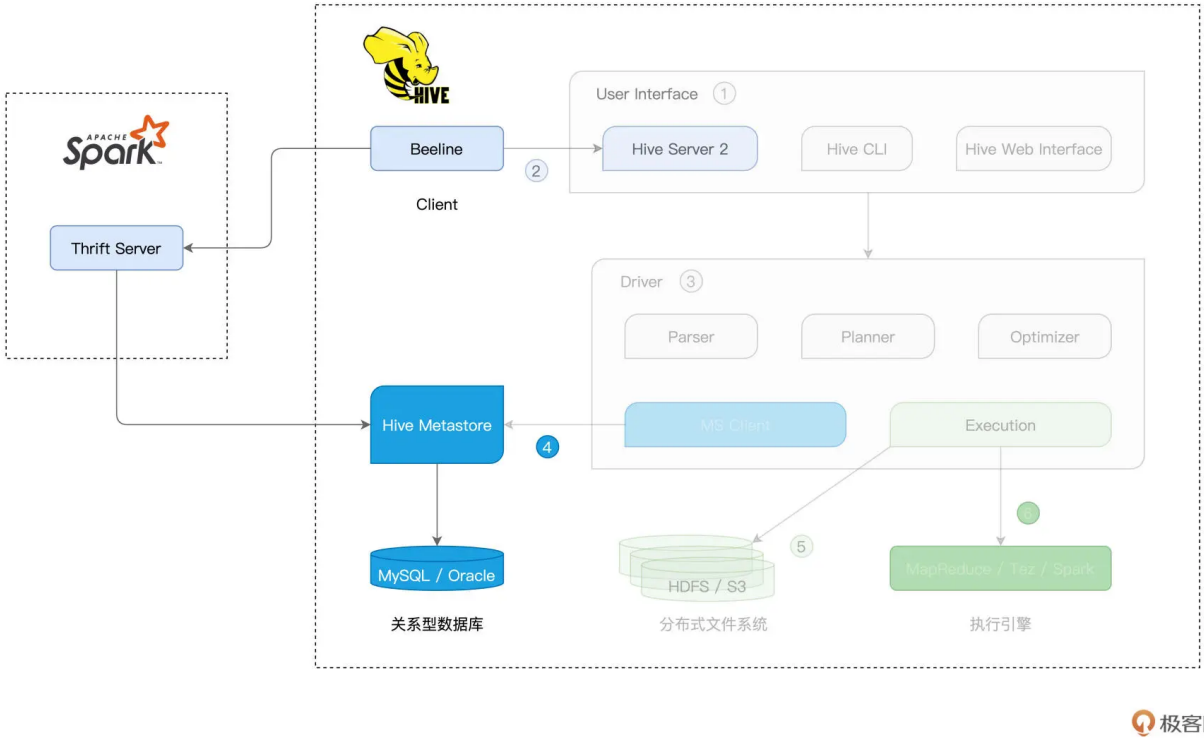

Beeline + Spark Thrift Server的集成方式

Spark Thrift Server 脱胎于 Hive Server 2，在接收查询、多租户服务、权限管理等方面，这两个服务端的实现逻辑几乎一模一样。它们最大的不同，在于 SQL 查询接入之后的解析、规划、优化与执行。

我们刚刚说过，Hive Server 2 的“后台”是 Hive 的那套基础架构。而 SQL 查询在接入到 Spark Thrift Server 之后，它首先会交由 Spark SQL 优化引擎进行一系列的优化。

在第 14 讲我们提过，借助于 Catalyst 与 Tungsten 这对“左膀右臂”，Spark SQL 对 SQL 查询语句先后进行语法解析、语法树构建、逻辑优化、物理优化、数据结构优化、以及执行代码优化，等等。然后，Spark SQL 将优化过后的执行计划，交付给 Spark Core 执行引擎付诸运行。

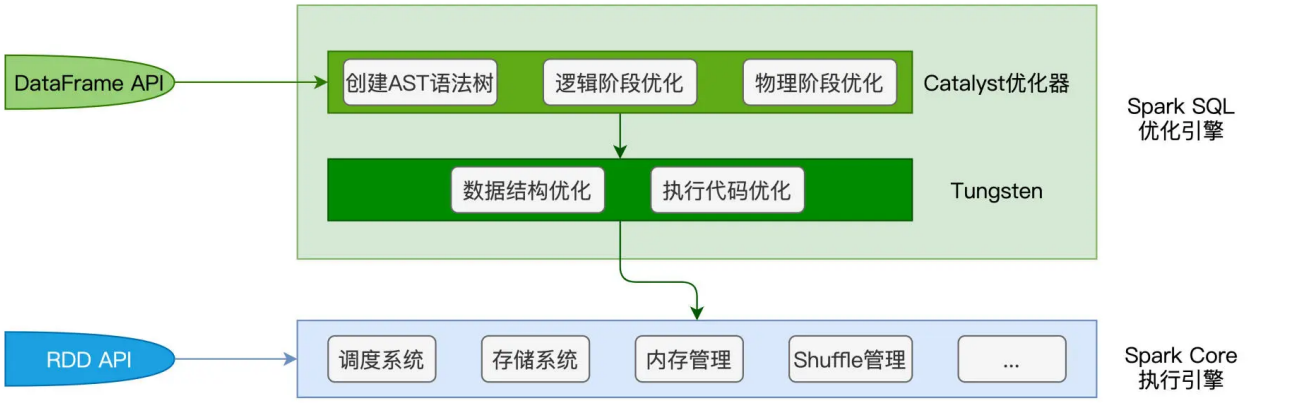

不难发现，SQL 查询在接入 Spark Thrift Server 之后的执行路径，与 DataFrame 在 Spark 中的执行路径是完全一致的。

理清了 Spark Thrift Server 与 Hive Server 2 之间的区别与联系之后，接下来，我们来说说 Spark Thrift Server 的启动与 Beeline 的具体用法。要启动 Spark Thrift Server，我们只需调用 Spark 提供的 start-thriftserver.sh 脚本即可。

复制代码

```
// SPARK_HOME环境变量，指向Spark安装目录
cd $SPARK_HOME/sbin

// 启动Spark Thrift Server
./start-thriftserver.sh
```

脚本执行成功之后，Spark Thrift Server 默认在 10000 端口监听 JDBC/ODBC 的连接请求。有意思的是，关于监听端口的设置，Spark 复用了 Hive 的 hive.server2.thrift.port

参数。与其他的 Hive 参数一样，hive.server2.thrift.port 同样要在 hive-site.xml 配置文件中设置。

一旦 Spark Thrift Server 启动成功，我们就可以在任意节点上通过 Beeline 客户端来访问该服务。在客户端与服务端之间成功建立连接（Connections）之后，咱们就能在 Beeline 客户端使用 SQL 语句处理 Hive 表了。需要注意的是，在这种集成模式下，SQL 语句背后的优化与计算引擎是 Spark。

```
/**
用Beeline客户端连接Spark Thrift Server，
其中，hostname是Spark Thrift Server服务所在节点
*/
beeline -u “jdbc:hive2://hostname:10000”
```

好啦，到此为止，Spark with Hive 这类集成方式我们就讲完了。

为了巩固刚刚学过的内容，咱们趁热打铁，一起来做个简单的小结。**不论是 SparkSession + Hive Metastore、spark-sql CLI + Hive Metastore，还是 Beeline + Spark Thrift Server，Spark 扮演的角色都是执行引擎，而 Hive 的作用主要在于通过 Metastore 提供底层数据集的元数据。不难发现，在这类集成方式中，Spark 唱“主角”，而 Hive 唱“配角”。**

Hive on Spark

说到这里，你可能会好奇：“对于 Hive 社区与 Spark 社区来说，大家都是平等的，那么有没有 Hive 唱主角，而 Spark 唱配角的时候呢？”还真有，这就是 Spark 与 Hive 集成的另一种形式：Hive on Spark。

基本原理

在这一讲的开头，我们简单介绍了 Hive 的基础架构。Hive 的松耦合设计，使得它的 Metastore、底层文件系统、以及执行引擎都是可插拔、可替换的。

在执行引擎方面，Hive 默认搭载的是 Hadoop MapReduce，但它同时也支持 Tez 和 Spark。所谓的“Hive on Spark”，实际上指的就是 Hive 采用 Spark 作为其后端的分布

式执行引擎，如下图所示。

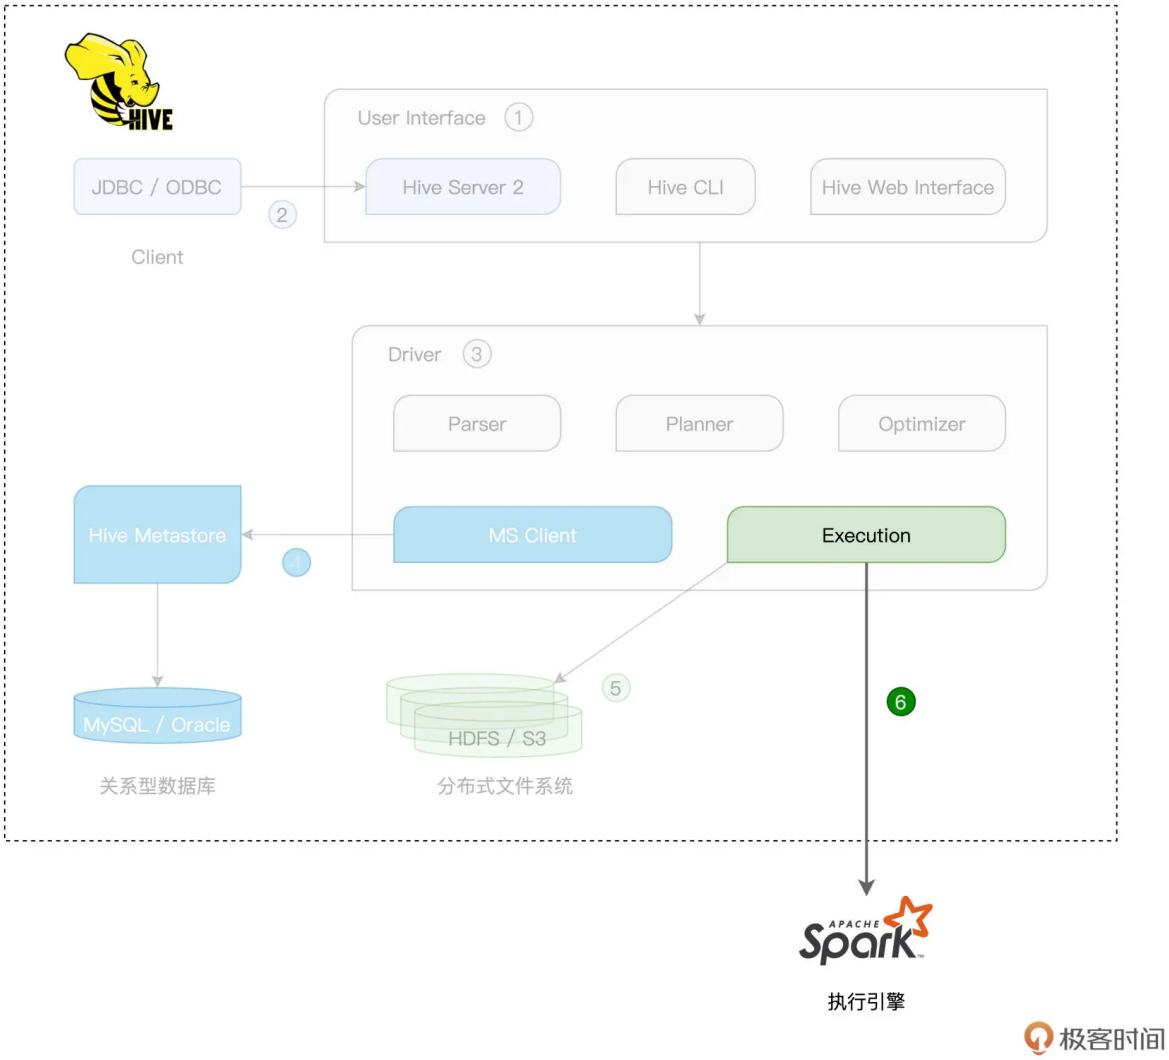

Hive on Spark系统架构

从用户的视角来看，使用 Hive on MapReduce 或是 Hive on Tez 与使用 Hive on Spark 没有任何区别，执行引擎的切换对用户来说是完全透明的。不论 Hive 选择哪一种执行引擎，引擎仅仅负责任务的分布式计算，SQL 语句的解析、规划与优化，通通由 Hive 的 Driver 来完成。

为了搭载不同的执行引擎，Hive 还需要做一些简单的适配，从而把优化过的执行计划“翻译”成底层计算引擎的语义。

举例来说，在 Hive on Spark 的集成方式中，Hive 在将 SQL 语句转换为执行计划之后，还需要把执行计划“翻译”成 RDD 语义下的 DAG，然后再把 DAG 交付给 Spark Core 付诸执行。从第 14 讲到现在，我们一直在强调，Spark SQL 除了扮演数据分析子框架的角色之外，还是 Spark 新一代的优化引擎。

在 Hive on Spark 这种集成模式下，Hive 与 Spark 衔接的部分是 Spark Core，而不是 Spark SQL，这一点需要我们特别注意。这也是为什么，相比 Hive on Spark，Spark with Hive 的集成在执行性能上会更胜一筹。毕竟，Spark SQL + Spark Core 这种原装组合，相比 Hive Driver + Spark Core 这种适配组合，在契合度上要更高一些。

集成实现

分析完原理之后，接下来，我们再来说说，Hive on Spark 的集成到底该怎么实现。

首先，既然我们想让 Hive 搭载 Spark，那么我们事先得准备好一套完备的 Spark 部署。对于 Spark 的部署模式，Hive 不做任何限定，Spark on Standalone、Spark on Yarn 或是 Spark on Kubernetest 都是可以的。

Spark 集群准备好之后，我们就可以通过修改 hive-site.xml 中相关的配置项，来轻松地完成 Hive on Spark 的集成，如下表所示。

配置项	含义
hive.execution.engine	指定Hive后端执行引擎，value = spark表示Hive on Spark
spark.master	指定Spark部署模式，如yarn或spark://hostname:port
spark.home	指定Spark安装目录

极客时间

Hive on Spark主要配置项

其中，hive.execution.engine 用于指定 Hive 后端执行引擎，可选值有“mapreduce”、“tez”和“spark”，显然，将该参数设置为“spark”，即表示采用 Hive on Spark 的集成方式。

确定了执行引擎之后，接下来我们自然要告诉 Hive：“Spark 集群部署在哪里”，spark.master 正是为了实现这个目的。另外，为了方便 Hive 调用 Spark 的相关脚本与 Jar 包，我们还需要通过 spark.home 参数来指定 Spark 的安装目录。

配置好这 3 个参数之后，我们就可以用 Hive SQL 向 Hive 提交查询请求，而 Hive 则是先通过访问 Metastore 在 Driver 端完成执行计划的制定与优化，然后再将其“翻译”为 RDD 语义下的 DAG，最后把 DAG 交给后端的 Spark 去执行分布式计算。

当你在终端看到“Hive on Spark”的字样时，就证明 Hive 后台的执行引擎确实是 Spark，如下图所示。

```
Query ID = centos_20210824093713_b031e6a7-8615-4d1c-9691-a406a796cc86
Total jobs = 1
Launching Job 1 out of 1
In order to change the average load for a reducer (in bytes):
  set hive.exec.reducers.bytes.per.reducer=<number>
In order to limit the maximum number of reducers:
  set hive.exec.reducers.max=<number>
In order to set a constant number of reducers:
  set mapreduce.job.reduces=<number>
Hive on Spark Session Web UI URL: http://ip-10-33-138-132.ec2.internal:4040

Query Hive on Spark job[0] stages: [0, 1]
Spark job[0] status = RUNNING
--------------------------------------------------------------------------------------
          STAGES   ATTEMPT        STATUS  TOTAL  COMPLETED  RUNNING  PENDING  FAILED
--------------------------------------------------------------------------------------
Stage-0 ........         0      FINISHED      1          1        0        0       0
Stage-1 ........         0      FINISHED      1          1        0        0       0
--------------------------------------------------------------------------------------
STAGES: 02/02    [==========================>>] 100%  ELAPSED TIME: 5.06 s
--------------------------------------------------------------------------------------
Spark job[0] finished successfully in 5.06 second(s)
OK
```

Hive on Spark示例截图

当然，除了上述 3 个配置项以外，Hive 还提供了更多的参数，用于微调它与 Spark 之间的交互。对于这些参数，你可以通过访问Hive on Spark 配置项列表来查看。不仅如此，在第 12 讲，我们详细介绍了 Spark 自身的基础配置项，这些配置项都可以配置到 hive-site.xml 中，方便你更细粒度地控制 Hive 与 Spark 之间的集成。

重点回顾

好啦，到此为止，今天的内容就全部讲完啦！内容有点多，我们一起来做个总结。

今天这一讲，你需要了解 Spark 与 Hive 常见的两类集成方式，Spark with Hive 和 Hive on Spark。前者由 Spark 社区主导，以 Spark 为主、Hive 为辅；后者则由 Hive 社区主导，以 Hive 为主、Spark 为辅。两类集成方式各有千秋，适用场景各有不同。

在 Spark with Hive 这类集成方式中，Spark 主要是利用 Hive Metastore 来扩充数据源，从而降低分布式文件的管理与维护成本，如路径管理、分区管理、Schema 维护，等等。

对于 Spark with Hive，我们至少有 3 种途径来实现 Spark 与 Hive 的集成，分别是 SparkSession + Hive Metastore，spark-sql CLI + Hive Metastore 和 Beeline + Spark Thrift Server。对于这 3 种集成方式，我把整理了表格，供你随时查看。

序号	实现途径	计算过程	适用场景
1	SparkSession + Hive Metastore	1.SparkSession通过访问Hive表直接创建DataFrame； 2.利用已有SQL API或DataFrame算子完成数据处理； 3.将计算结果再存储到Hive表	适合数据仓库中的ETL场景，开发者从Hive中读取细粒度的源数据，完成数仓中典型的加载、抽取与转换的计算过程
2	spark-sql CLI + Hive Metastore	通过spark-sql CLI来访问本地Hive Metastore	由于本地性限制，这种集成方式不适合部署到生产系统，往往用于部署前期的连通性测试
3	Beeline + Spark Thrift Server	JDBC/ODBC客户端，如Beeline，可以通过连接Spark Thrift Server来提交即席查询，方便数据分析师、数据科学家快速完成数据探索、数据分析过程	即席查询 (Ad-hoc Queries)

极客时间

Spark with Hive实现途径

与 Spark with Hive 相对，另一类集成方式是 Hive on Spark。这种集成方式，本质上是 Hive 社区为 Hive 用户提供了一种新的选项，这个选项就是，在执行引擎方面，除了原有的 MapReduce 与 Tez，开发者还可以选择执行性能更佳的 Spark。

因此，在 Spark 大行其道的当下，习惯使用 Hive 的团队与开发者，更愿意去尝试和采用 Spark 作为后端的执行引擎。

熟悉了不同集成方式的区别与适用场景之后，在日后的工作中，当你需要将 Spark 与 Hive 做集成的时候，就可以做到有的放矢、有章可循，加油。

每课一练

1. 在 Hive on Spark 的部署模式下，用另外一套 Spark 部署去访问 Hive Metastore，比如，通过创建 SparkSession 并访问 Hive Metastore 来扩充数据源。那么，在这种情况下，你能大概说一说用户代码的执行路径吗？

2. 尽管咱们专栏的主题是 Spark，但我强烈建议你学习并牢记 Hive 的架构设计。松耦合的设计理念让 Hive 本身非常轻量的同时，还给予了 Hive 极大的扩展能力。也正因如此，Hive 才能一直牢牢占据开源数仓霸主的地位。Hive 的设计思想是非常值得我们好好学习

的，这样的设计思想可以推而广之，应用到任何需要考虑架构设计的地方，不论是前端、后端，还是大数据与机器学习。

欢迎你在留言区跟我交流互动，也欢迎把这一讲的内容分享给更多同事、朋友。

分享给需要的人，Ta订阅后你可得 20 元现金奖励

生成海报并分享

赞 1 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 19 | 配置项详解：哪些参数会影响应用程序执行性能？

精选留言 (2)

写留言

qinsi

2021-10-26

理论上应该可以把HQL转换成Spark SQL吧，那样Hive on Spark是不是性能就会提升了？

gouge

2021-10-26

老师，请问为什么会有这个限制？“spark-sql CLI 的集成方式多了一层限制，那就是在部署上，spark-sql CLI 与 Hive Metastore 必须安装在同一个计算节点”。

我实验好像没有发现存在这个“限制”。如下：

...

展开